

BUNDESREPUBLIK DEUTSCHLAND

REC'D PCT/PTO 19 SEP 2005

10/549679**PRIORITY
DOCUMENT**SUBMITTED OR TRANSMITTED IN
COMPLIANCE WITH RULE 17.1(a) OR (b)

REC'D 18 MAR 2004

WIPO

PCT

**Prioritätsbescheinigung über die Einreichung
einer Patentanmeldung****Aktenzeichen:**

103 11 698.2

Anmeldetag:

17. März 2003

Anmelder/Inhaber:Siemens Aktiengesellschaft,
80333 München/DE**Bezeichnung:**Sprachrückmeldung bei der sprecherunabhängigen
Namenswahl**IPC:**

G 06 F 17/20

**Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ur-
sprünglichen Unterlagen dieser Patentanmeldung.**München, den 12. Februar 2004
Deutsches Patent- und Markenamt
Der Präsident
Im Auftrag

A stylized handwritten signature in black ink.

Deutsches

Beschreibung

Sprachrückmeldung bei der sprecherunabhängigen Namenswahl

5 Die Technologie der Spracherkennung für mobile Endgeräte ist mittlerweile so weit fortgeschritten, dass es möglich ist, eine sprecherunabhängige Namenswahl (Speaker Independent Name Dialing) zu realisieren. Einträge des Adressbuches können dabei direkt durch Sprechen des eingetragenen Namens gewählt
10 werden, ohne dass zuvor beim Benutzer ein Training des Sprachmusters durchgeführt werden muss.

Allerdings wird bei einer solchen Form der Spracherkennung der Handsfree-Modus eingeschränkt, da der Benutzer zur
15 Verifizierung des Erkennungsergebnisses auf die Rückmeldung im Display angewiesen ist und keine akustische Rückmeldung des erkannten Eintrages erhält.

Um eine akustische Rückmeldung für die sprecherunabhängige Namenswahl zu realisieren, wird heute davon ausgegangen, dass
20 Text-zu-Sprache (Text-to-Speech; TTS)-Komponenten zum Einsatz kommen müssen. Diese TTS-Komponenten generieren aus einem Text eine synthetische Sprachausgabe. Der erkannte Namenseintrag eines Adressbuches kann damit synthetisiert ausgegeben werden. Die einzusetzenden TTS-Komponenten benötigen jedoch eine für mobile Endgeräte und eingebettete Hardware hohe Rechenleistung sowie großen Speicherbedarf und sind damit nur sehr kostenintensiv zu realisieren. Die Sprachqualität solcher TTS-Systeme für mobile Geräte ist
30 darüber hinaus wegen des kleinen Footprints auf einem geringen Niveau. Weiterhin werden ausländische Namen durch TTS-Systeme vielfach ungewohnt und fehlerhaft ausgesprochen.

Davon ausgehend liegt der Erfindung die Aufgabe zugrunde,
35 eine Sprachrückmeldung für eine erkannte Spracheingabe möglichst ressourcenschonend zu realisieren.

Diese Aufgabe wird durch die in den unabhängigen Patentansprüchen angegebenen Erfindungen gelöst. Vorteilhafte Ausgestaltungen ergeben sich aus den Unteransprüchen.

5 Dementsprechend wird in einem Verfahren zur Spracherkennung, insbesondere auf eingebetteter Hardware und/oder einem mobilen Endgerät, durch einen Benutzer ein erstes Sprachsignal mittels Einsprechen eingegeben. Die Bezeichnung „erstes“ Sprachsignal dient lediglich dazu, das Sprachsignal
10 im Rahmen dieses Textes von weiteren, folgenden Sprachsignalen zu unterscheiden. Das eingegebene erste Sprachsignal wird erkannt, indem es einem Erkennungseintrag zugeordnet wird, und aufgenommen, indem Daten abgespeichert werden, die zur akustischen Repräsentation des Sprachsignals
15 benötigt werden. Die Aufnahme des eingegebenen ersten Sprachsignals wird schließlich als dem Erkennungseintrag zugeordnet gespeichert. Dadurch steht sie für spätere Erkennungen als Bestätigungssignal in Form einer Sprachrückmeldung zur Verfügung.

20 Vorzugsweise wird die Aufnahme des eingegebenen ersten Sprachsignals nur dann als dem Erkennungseintrag zugeordnet gespeichert, wenn vom Benutzer bestätigt wird, dass das eingegebene erste Sprachsignal richtig erkannt wurde. Alternativ oder ergänzend kann die Abspeicherung eines fälschlich einem Erkennungseintrag zugeordneten Sprachsignals später auch wieder gelöscht werden.

30 Insbesondere vor der Bestätigung, dass das eingegebene Sprachsignal richtig erkannt wurde, lässt sich eine optische Repräsentation des Erkennungseintrags auf einer Anzeige ausgeben. Der Benutzer kann dadurch die optische Repräsentation des Erkennungseintrags lesen und danach bestätigen, dass das Sprachsignal richtig erkannt wurde.

35 Nach dem Abspeichern und Erkennen des ursprünglichen Sprachsignals gestalten sich Spracherkennungsvorgänge von

weiteren, dem ersten Sprachsignal gleichen oder ähnlichen Sprachsignalen wie folgt: Vom Benutzer wird ein weiteres Sprachsignal eingegeben. Das weitere eingegebene Sprachsignal wird erkannt, indem es dem Erkennungseintrag zugeordnet wird.

5 Schließlich wird die als dem Erkennungseintrag zugeordnet gespeicherte Aufnahme des eingegebenen ersten Sprachsignals zur Bestätigung, dass das weitere eingegebene Sprachsignal als der Erkennungseintrag erkannt wurde, akustisch ausgegeben.

10

Zusätzlich zu der oben beschriebenen automatischen Zuordnung und Abspeicherung von Sprachsignalen kann dem Benutzer die Möglichkeit gegeben werden, explizit selbst Sprachsignale aufzunehmen und sie manuell Erkennungseinträgen zuzuordnen.

15 Dazu ist zu einem weiteren Erkennungseintrag ohne zwischengeschaltete Spracherkennung ein gewünschtes Sprachsignal eingebbar und abspeicherbar.

Das Verfahren ist insbesondere ein Verfahren zur sprecherunabhängigen Namenswahl. Es lässt sich aber auch für
20 alle anderen Anwendungsgebiete der, insbesondere sprecherunabhängigen, Spracherkennung anwenden, bei denen eine Sprachrückmeldung zur Realisierung eines "Full Handsfree"-Modus benötigt wird, wie beispielsweise bei Command & Control, bei Sprachlinks (Voice Links), insbesondere bei der Internetnavigation, bei der Sprachwahl von Anwendungen (Speech Application Selection) und/oder bei der Spracheingabe von Stadt- und Straßennamen (City Name Input).

30

Eine Vorrichtung, die eingerichtet ist und Mittel aufweist, das geschilderte Verfahren auszuführen, lässt sich beispielsweise durch entsprechendes Programmieren und Einrichten einer Datenverarbeitungsanlage realisieren. Die
35 Vorrichtung weist dabei insbesondere Mittel zur Eingabe des Sprachsignals, Mittel zum Erkennen des Sprachsignals durch Zuordnen zu einem Erkennungseintrag und Speichermittel auf,

in denen das eingegebene Sprachsignal zu dem Erkennungseintrag abspeicherbar ist. Vorteilhafte Ausgestaltungen der Vorrichtung ergeben sich analog zu den vorteilhaften Ausgestaltungen des Verfahrens.

5

Die Vorrichtung ist insbesondere ein mobiles Endgerät, vorzugsweise eine mobile Kommunikationseinrichtung, etwa in Form eines Mobiltelefons und/oder PDAs oder eine mobile Navigationseinrichtung in Form eines Navigationssystems in einem Fahrzeug.

10

Ein Programmprodukt für eine Datenverarbeitungsanlage, das Codeabschnitte enthält, mit denen eines der geschilderten Verfahren auf der Datenverarbeitungsanlage ausgeführt werden kann, lässt sich durch geeignete Implementierung des Verfahrens in einer Programmiersprache und Übersetzung in von der Datenverarbeitungsanlage ausführbaren Code ausführen. Die Codeabschnitte werden dazu gespeichert. Dabei wird unter einem Programmprodukt das Programm als handelbares Produkt verstanden. Es kann in beliebiger Form vorliegen, so zum Beispiel auf Papier, einem computerlesbaren Datenträger oder über ein Netz verteilt.

15

20

Weitere Vorteile und Merkmale der Erfindung ergeben sich aus der Beschreibung eines Ausführungsbeispiels.

Durch die Erfindung kann bei der sprecherunabhängigen Namenswahl ohne die Verwendung von TTS-Komponenten schrittweise eine Sprachrückmeldung kostengünstig realisiert werden.

30

Ein durch einen Benutzer gesprochener Name wird dazu bei einer Sprachwahl nicht nur dem Spracherkenner zugeführt, sondern er wird zusätzlich parallel auch als Sprachkonserve mitgeschnitten. Bei der erstmaligen Namenswahl eines Adressbucheintrages wird der vom Spracherkenner erkannte Namenseintrag optisch dem Benutzer im Display angezeigt.

35

Darüber hinaus wird der Benutzer akustisch mit einem Tonsignal aufgefordert, das Erkennungsergebnis zu bestätigen. Bestätigt der Benutzer das Ergebnis, wird der erkannte Adressbucheintrag gewählt und die Aufnahme des eingegebenen Sprachsignals in Form der aufgenommenen Sprachkonserve dem Erkennungseintrag in Form des Adressbucheintrages zugeordnet. Bei jeder weiteren Namenswahl dieses Eintrages kann nun neben der optischen Rückmeldung auch die zugeordnete Sprachkonserve als Sprachrückmeldung verwendet werden. Der Benutzer wird dadurch sowohl visuell als auch akustisch über das Erkennungsergebnis informiert. Es lässt sich damit ein Full Handsfree-Modus erreichen, der eine korrekte, qualitativ hochwertige Sprachwiedergabe besitzt. Durch die zuverlässig zugeordnete Sprachkonserve des Benutzers kann dabei auf die kostenintensive TTS-Komponente verzichtet werden.

Die Erfindung beruht also auf einem selbstinitiiierenden System, das auf der Kombination des Sprachmitschnittes bei der Spracherkennung und der zuverlässigen Zuordnung eines Sprachmitschnittes durch die Bestätigung des Erkennungsergebnisses basiert.

Dies soll nochmals an einem weiter konkretisierten Ausführungsbeispiel erläutert werden. In einem Mobiltelefon werden mittels eines sprecherunabhängigen, HMM-basierten Spracherkenners Funktionen der sprecherunabhängigen Namenswahl implementiert. Alle Namen im Adressbuch des Benutzers werden dem Spracherkenner über eine Graphem-zu-Phonem-Technologie bekannt gemacht und können damit direkt per Sprache gewählt werden.

Im Initialzustand des Systems existieren keine Sprachkonserven zu den Adressbucheinträgen. Bei Aktivierung der Funktionalität zur sprecherunabhängigen Namenswahl wird der durch den Benutzer gesprochene Name dem Spracherkenner zugeführt und parallel als Sprachkonserve mitgeschnitten. Der Spracherkenner liefert das Erkennungsergebnis zurück und es

wird überprüft, ob zu dem Erkennungsergebnis bereits eine Sprachkonserve vorliegt.

- Existiert noch keine Sprachkonserve, wird das
- 5 Erkennungsergebnis auf dem Display angezeigt und der Benutzer mit einem Voice Prompt wie zum Beispiel "Erkennung bestätigen" oder "Wählen" aufgefordert, das Erkennungsergebnis zu bestätigen. Wird das Ergebnis durch die Taste "Wählen" bestätigt, wird die Sprachkonserve dem
- 10 Adressbucheintrag zugeordnet und die Nummer wird gewählt. Wird das Ergebnis durch die Taste "Abbrechen" nicht bestätigt, wird die Sprachkonserve gelöscht und kein Wahlvorgang durchgeführt.
- 15 Ist zu einem erkannten Adressbucheintrag bereits eine Sprachkonserve zugeordnet, wird diese neben der Displayanzeige dem Benutzer vorgespielt. Der Wahlvorgang wird danach automatisch gestartet. Durch die Sprachrückmeldung (Voice Feedback) hat der Benutzer auch im Handsfree-Betrieb
- 20 die Möglichkeit, einfach zu überprüfen, ob das Erkennungsergebnis korrekt ist. Während des gestarteten Wahlvorgangs bleibt dem Benutzer in der Regel genügend Zeit, den Wahlvorgang im Falle einer Fehlerkennung noch abubrechen.
- Zusätzlich zu der oben beschriebenen automatischen Zuordnung von Sprachkonserven kann dem Benutzer die Möglichkeit angeboten werden, explizit selbst Sprachkonserven aufzunehmen und manuell zuzuordnen.
- 30
- Verwenden mehrere Benutzer ein Gerät, können Benutzerprofile angelegt werden, bei denen für jeden Benutzer individuell seine eigenen Sprachkonserven im jeweiligen Profil hinterlegt werden. Damit lässt sich ein Stimmenmix vermeiden und ein
- 35 homogenes akustisches Klangbild erreichen.

Patentansprüche

1. Verfahren zur sprecherunabhängigen Spracherkennung,
insbesondere auf eingebetteter Hardware und/oder einem
5 mobilen Endgerät,
 - bei dem ein erstes Sprachsignal eingegeben wird,
 - bei dem das eingegebene erste Sprachsignal aufgenommen wird
und erkannt wird, indem es einem Erkennungseintrag zugeordnet
wird,
 - 10 - bei dem die Aufnahme des eingegebenen ersten Sprachsignals
als dem Erkennungseintrag zugeordnet gespeichert wird.
2. Verfahren nach Anspruch 1,
bei dem die Aufnahme des eingegebenen ersten Sprachsignals
15 nur dann als dem Erkennungseintrag zugeordnet gespeichert
wird, wenn bestätigt wird, dass das eingegebene erste
Sprachsignal richtig erkannt wurde.
3. Verfahren nach einem der vorhergehenden Ansprüche,
20 bei dem eine optische Repräsentation des Erkennungseintrags
ausgegeben wird.
4. Verfahren nach einem der vorhergehenden Ansprüche,
 - bei dem ein weiteres Sprachsignal eingegeben wird,
 - bei dem das weitere eingegebene Sprachsignal erkannt wird,
indem es dem Erkennungseintrag zugeordnet wird,
 - bei dem die als dem Erkennungseintrag zugeordnet
gespeicherte Aufnahme des eingegebenen ersten Sprachsignals
ausgegeben wird.
- 30 5. Verfahren nach einem der vorhergehenden Ansprüche,
bei dem zu einem weiteren Erkennungseintrag ohne
zwischengeschaltete Spracherkennung ein gewünschtes
Sprachsignal eingebbar und abspeicherbar ist.

6. Verfahren nach einem der vorhergehenden Ansprüche, bei dem das Verfahren ein Verfahren zur Namenswahl, insbesondere für eine Kommunikationseinrichtung, ist, insbesondere ein Verfahren zur sprecherunabhängigen Namenswahl.

7. Verfahren nach einem der Ansprüche 1 bis 5, bei dem das Verfahren ein Verfahren zur Eingabe von Stadt- und/oder Straßennamen ist, insbesondere ein Verfahren zur sprecherunabhängigen Eingabe von Stadt- und/oder Straßennamen.

8. Verfahren nach einem der Ansprüche 1 bis 5, bei dem das Verfahren ein Verfahren zur sprachgestützten Applikationssteuerung ist.

9. Verfahren nach einem der Ansprüche 1 bis 5, bei dem das Verfahren ein Verfahren zur sprachgesteuerten Auswahl von Internet Links (Voice Links) ist.

10. Vorrichtung, die eingerichtet ist und Mittel aufweist, so dass ein Verfahren nach einem der Ansprüche 1 bis 7 ausführbar ist.

11. Vorrichtung nach Anspruch 10, die ein mobiles Endgerät ist, insbesondere eine mobile Kommunikationseinrichtung und/oder mobile Navigationseinrichtung.

12. Programmprodukt, das, wenn es auf eine Datenverarbeitungsanlage geladen und darauf ausgeführt wird, ein Verfahren nach einem der Ansprüche 1 bis 9 oder eine Vorrichtung nach einem der Ansprüche 10 oder 11 in Kraft setzt.

Zusammenfassung

Sprachrückmeldung bei der sprecherunabhängigen Namenswahl

- 5 Eine erstmalige Spracheingabe wird bei der Spracherkennung einem Erkennungseintrag zugeordnet und ihre Aufnahme zu diesem Erkennungseintrag abgespeichert, so dass sie bei weiteren Erkennungsvorgängen als Rückmeldung ausgebar ist.